

UDK 330.115

Pregledni članak

Primljeno 12. lipnja 1988.

Dr. BRANKO NOVAK
Ekonomski fakultet Osijek

SISTEMSKA DINAMIKA I EKONOMETRIJSKI MODELI U MODELIRANJU EKONOMSKIH SISTEMA*

Članak analizira dva moguća pristupa modeliranju ekonomskih sistema. To su ekonometrijski pristup i pristup preko ideja sistemske dinamike. Prvi se šire primjenjuje i u svjetskoj i domaćoj praksi. Ekonometrijski pristup temelji se na realnim, mjerljivim činjenicama. Zato ovdje postoji trajan zahtjev za više podataka, za boljim mjerenjem, za novim podacima. Ekonometrijski pristup ekonomskim modelima odražava shvaćanje da je svijet u suštini dualan i otvoren. Kako ulazi iz okruženja u sistem mogu biti vrlo specifični, ekonometrijskim modelima istražuju se osobitosti, a manje sličnosti različitih situacija. Sistemska dinamika kao potencijalni pristup modeliranju ekonomskih sistema polazi od stajališta da kvantitativni podaci čine manji dio onoga što znamo, pa se oslanja na razne izvore podataka. Ona, nadalje, nastoji objasniti ponašanje vidljivih dinamičkih varijabli sistema strukturom sistema u čijoj su osnovi brojne petlje informacijskih povratnih veza. U strukturi modela sistemske dinamike jasno se pravi razlika između varijabli stokova i varijabli tokova. Sistemska dinamika polazi od pretpostavke da su sistemi prvenstveno zatvoreni, pa se pažnja u ovim modelima poklanja generalnim reakcijama na generalna uznemirenja, te dinamičkom ponašanju reakcija, a ne konačnom stanju sistema.

* Rad predstavlja dio istraživačkih rezultata potprojekta »Zakon vrijednosti u funkciji upravljanja razvojem«, kojeg kao dio projekta »Fundamentalna istraživanja u ekonomiji« financira SIZ znanosti SR Hrvatske u razdoblju 1987-1990. godine.

1. Uvodne napomene

Ekonomski modeli su danas vrlo snažno oruđe ekonomske analize. Oni u svojoj suštini predstavljaju pojednostavljenje kauzalnih sistema. U osnovi modeli ekonomskih sistema mogu se podijeliti na:

- matematičke, i
- ekonometrijske.

U matematičkim modelima veze između varijabli (ekonomskih) funkcionalne su. U ekonometrijskim modelima veze između varijabli stohastičke su, što znači da vrijede samo približno odnosno da vrijede s određenom vjerojatnošću. Ekonometrijski model može biti izražen samo jednom relacijom (jednadžbom), ali ovi modeli dobivaju značajno na analitičkoj snazi kada se sastoje iz sistema relacija (jednadžbi). U ovom području u svijetu, ali i u Jugoslaviji izvršena su značajna istraživanja, koja su rezultirala vrlo složenim ekonometrijskim modelima čitavih narodnih privreda. No, u posljednjih trideset godina razvijena je u svijetu sistemska dinamika kao pristup modeliranju dinamičkih sistema. Njena primjena je, međutim, daleko manja u analizi ponašanja ekonomskih sistema. Čini se da za ovakav odnos prema sistemske dinamici u ekonomskim istraživanjima nema dovoljno razloga. U nastavku pokušat ćemo objasniti odnos između ova dva pristupa modeliranju ekonomskih sistema te ukazati na njihove srodnosti, razlike i mogućnost međusobnog nadopunjavanja. Dodatna pažnja bit će poklonjena karakteristikama sistemske dinamike.

2. Ekonometrijski modeli

Ekonometrija se prvenstveno temelji na realnosti čije manifestacije možemo na neki način promatrati i mjeriti. Naravno, ekonometrija može slobodno spekulirati o nevidljivim psihološkim i fizičkim mehanizmima, ali zaključke o teoriji kauzalnih veza izvlači iz ekonomije. Međutim, ekonometrijski modeli ne mogu eksplicitno sadržavati ono što se nagađa, već samo ono što se zna, a u ovom obrascu mišljenja može se znati samo ono što se može mjeriti. Zato ekonometrijski modeli, na neki način predstavljaju samo površinu fenomena, a kauzalna struktura implicitno se podrazumijeva. Ne postoje čvrsti pojmovi o prirodi te strukture. Zato

se u ekonometriji osjeća neprekidna potreba za više podataka, za boljim mjerenjem, za novim podacima, boljem pristupu bazama podataka, itd. Pretpostavke ekonometrije odražavaju uobičajeno shvaćanje da je svijet u svojoj suštini dualan i otvoren. Zato se pravi oštra razlika između privrede i okruženja (države, stanovništva, svjetske privrede, itd.). S obzirom da okruženje utječe na sistem, u modelu se okruženje pojavljuje kroz ulaze u model (egzogene varijable), na koje sistem odnosno model reagira na određeni način. Kako svaki sistem, ulaz i reakcija mogu biti specifični, modelom se obično obavlja istraživanje osobitosti, a manje sličnosti različitih situacija.

S obzirom na brojne nedostatke podataka na kojima se temelje ekonometrijski modeli, ekonometrija je razvila različite statističke tehnike i postupke kojima rješava ove slabosti (dvostepena i trostepena metoda najmanjih kvadrata, metode otklanjanja utjecaja autokorelacije i multikolinearnosti, nelinearne metode najmanjih kvadrata, postupci kada nedostaju promatranja, povezivanje sektorskih podataka sa podacima koji su u vremenskim serijama, postupci s distribuiranim lagovima, modeli binarnog izbora, itd.). Osim toga ekonometrija je razvila i brojne tehnike za validaciju (ocjenu valjanosti) modela te analizu rezultata koji se dobiju u fazi korištenja (eksperimentiranja) modela. U ovim područjima ekonometrija je bez svake sumnje ostvarila izuzetne rezultate.

3. Sistemska dinamika

U SAD se prije trideset godina javila još jedna metoda modeliranja ponašanja dinamičkih sistema. Radi se o metodi sistemske dinamike, ili kako se u početku ova metoda nazivala »industrijska dinamika.«¹ Ovaj pristup modeliranju primjenjivao se prvenstveno u istraživanju ponašanja dinamičkih proizvodnih sistema u industriji po čemu je i dobio naziv industrijska dinamika. Zatim se isti pristup počeo primjenjivati i na istraživanje svjetske dinamike² odnosno na istraživanje dinamičkog uzajamnog djelovanja kretanja svjetskog stanovništva, poljoprivredne i industrijske proizvodnje, obnovljivih sirovina, zagađivanja čovjekove okoline i zemljišnih površina. Ova istraživanja vršena su u okviru takozvanog Rim-

skog kluba. Sama sistemska dinamika temelji se na tri dostignuća teorije i prakse koja su se javila prije nje:

- tradicionalno upravljanje društvenim sistemima,
- kibernetika, odnosno teorija informacijske povratne veze i
- kompjuterske simulacije.

U obrazloženju osnovnih ideja sistemske dinamike poći ćemo od podataka kao osnove za izgradnju modela, što je od izuzetne važnosti u ekonometrijskim modelima. Sistemska dinamika polazi od stava, kojemu se teško što može zamjeriti, a to je da statistički podaci čine mali dio onoga što znamo. Zato ona uranja u niže razine nemjerljivih kauzalnih veza, a pritom se služi teorijama koje omogućavaju da se povežu vidljive dinamičke varijable u sistemima s nevidljivom strukturom petlji informacijske povratne veze. Ona nastoji postaviti tu strukturu te je eksplicitno uključiti u modele. Sistemska dinamika nastoji utvrditi univerzalne opće veze, pa zato koristi podatke iz bilo kojeg razdoblja i podсистема, uključujući uz ostale izvore i iste statističke podatke na temelju kojih se grade ekonometrijski modeli. Međutim, ovaj pristup općenito preferira direktna, kvalitativna promatranja fizičkih procesa i aktera u stvarnom sistemu. Sistemska dinamika nastoji koristiti cijeli spektar informacija raznih preciznosti, koje idu od intuicije i slučajnih promatranja na jednoj strani, do kontroliranih fizičkih mjerenja na drugoj, a gdje je društvena statistika negdje u sredini ovog spektra. Pristup na temelju ideja sistemske dinamike polazi od shvaćanja da ovaj spektar nudi daleko više informacija nego što se obično koristi, te da realna potreba nije da dobijemo više podataka nego da bolje koristimo raspoložive podatke.

Ideje sistemske dinamike polaze od pretpostavke da su sistemi prvenstveno zatvoreni — ne samo da okruženje utječe na njih, nego i oni utječu na okruženje. Zapravo, razlika između sistema i okruženja rijetko kada je jasna. Pažnja u modelima koji se temelje na idejama sistemske dinamike poklanja se generalnim reakcijama sistema na generalna uznemirenja, i dinamičkom ponašanju reakcija, a ne njegovom konačnom stanju.

Mogli bismo reći da su modeli na idejama sistemske dinamike komplementarni ekonometrijskim modelima na nekoliko načina. Naime, sistemska dinamika daje teoriju kauzalne strukture i njenu vezu s dinamičkim ponašanjem, što je snažno oruđe specifikacije modela. Ekonometrija daje brojne tehnike za određivanje empirijskih

1) Vidi o tome opširnije: Forrester, J. W.: *Industrial Dynamics*, Cambridge: MIT Press 1961.

2) Vidi o tome opširnije: Meadows, D. H., Meadows, D. L., Randers, J. i Berens III, W.: *Granice rasta*, Stvarnost, Zagreb 1974.

parametara te za formalnu usporedbu rezultata modela i ponašanja stvarnog sistema. Prva od ovih tehnika je naročito pogodna za dugoročne analize mogućih promjena povijesnih trendova. Druga je najpogodnija za kratkoročna precizna predviđanja u situacijama koje se bitno ne razlikuju od prošlih situacija. Moguće je da korištenje ove dvije metode zajedno može dati modele koji kombiniraju realističnu strukturu s točnim parametrima. Ovi modeli bi se mogli koristiti u svakoj fazi odlučivanja pogotovo za srednjoročne probleme. Time bismo u ekonomsku analizu uveli jednu novu tehniku, nov pristup i pogled koji zaslužuje značajnu pažnju s obzirom na potencijalne koristi ovakvog pristupa. Pri tom nije bitno da li se u nekom konkretnom slučaju više koristi sistemska dinamika ili ekonometrija, bitno je da se ovakvom kombinacijom ideja napadnu stvarni ekonomski problemi te doprinese njihovom rješavanju. Naravno, s obzirom na karakteristike jednog i drugog pristupa, istraživanja koja bi se temeljila na njihovoj kombinaciji bila bi dominantno dinamička.

4. Elementi sistemske dinamike

S obzirom da je ekonometrijski pristup modeliranju dosta obađivan u jugoslavenskoj literaturi³ u nastavku će detaljnije biti objašnjena sistemska dinamika koja je daleko manje primjenjivana i obrađivana u domaćoj literaturi.

Sistemska dinamika je metoda koja se hvata u koštac s pitanjima dinamičkih tendencija složenih sistema, odnosno, njihovim ponašanjem tokom vremena. Sistemska dinamika se općenito ne bavi preciznim numeričkim vrijednostima varijabli sistema u određenoj godini. Ona je daleko više zainteresirana za opće dinamičke tendencije, bez obzira da li je sistem kao cjelina stabilan ili nestabilan, oscilirajući, rastući, opadajući ili je u ravnoteži.

Primarna pretpostavka sistemske dinamike je da trajne dinamičke tendencije bilo kojeg složenog sistema proizlaze iz njegove kauzalne strukture i iz fizičkih ograničenja i društvenih ciljeva, poticaja i pritisaka, koji uzrokuju da se ljudi ponašaju na određeni način i da kumulativno generiraju dominantne dinamičke tendencije cijelog sistema. Sistemska dinamika traži objašnjenja dugoročnih društvenih problema unutar te strukture, a ne u vanjskim uzemljenjima ili slučajnim događajima.

Osnovna koncepcija koju sistemska dinamika koristi da bi se shvatila struktura sistema je ideja informacijske povratne veze. U sistemima, pa tako i u modelima, može postojati dvije vrste informacijske povratne veze. Prve su pozitivne, samoobnavljajuće petlje povratne veze koje pojačavaju svako uznemirenje te time proizvode eksponencijalni rast. Druge su negativne, ili petlje povratne veze koje traže cilj. Točnije u ovim petljama povratne veze postoji tendencija da se ostvari određeni cilj, ublaži svako uznemirenje, a sistem usmjeri prema ravnotežnoj točki ili cilju. U modelima sistemske dinamike često se javljaju određene kombinacije ove dvije vrste petlji povratne veze, što omogućava da se formuliraju brojne korisne generalizacije ili teoremi koji povezuju strukturu sistema s tendencijama ponašanja dinamičkih sistema. Na primjer, kada sistem pokazuje eksponencijalni rast, analitičar sistema automatski će tražiti dominantnu pozitivnu petlju povratne veze. Tendencija sistema da se vrati u svoje prvobitno stanje nakon uznemirenja ukazuje na prisutnost najmanje jedne jake negativne petlje povratne veze. Oscilatorno ponašanje obično ukazuje na postojanje negativne petlje povratne veze s vremenski odloženim djelovanjem — dilacijom⁴. Rast S-oblika rezultira iz povezanih pozitivnih i negativnih petlji povratne veze koje reagiraju jedna na drugu nelinearno i bez značajnih vremenskih dilacija.

4.1. Struktura modela na idejama sistemske dinamike

Osnovnu strukturu modela dinamičkih sistema čine struktura rezervoara, ili nivoa, ili stokova koji su međusobno povezani kontroliranim tokovima. Prema tome, ovi modeli, za razliku od ekonometrijskih modela, strogo razlikuju stokove i tokove.⁵ Postoje četiri osnovne karakteristike modela sistemske dinamike:

- modeli sadrže nekoliko nivoa, odnosno stokova,
- tokovi obavljaju transport sadržaja jednog stoka u drugi stok,

4) Engl. delay. O tome vidjeti opširnije u Forrester J.: *Industrial Dynamics*, str. 83–92 i 418–421.

5) Kada se u ekonomskim modelima pažljivo razlikuju stokovi i tokovi (fizički i informacijski), ponašanje koje oni pokazuju bitno se razlikuje od onog kod ispuštanja ove razlike. To je pokazao Low W. G. na primjeru Hicksove verzije Samuelsonovog modela. O tome vidjeti u Low, W. G.: *The Multiplier-Accelerator Model of Business Cycles Interpreted from a Systems Dynamics Perspective*, u Randers, J. *Elements of System Dynamics Method*, The MIT Press, Cambridge, 1980.

3) Babić M., Bole V., Mencinger J., Pfajfar L., Kranjec M., Kuzmin F., Simončić M. i Kebrić I., Sojić M., Jovićić M., i drugi.

- postoje funkcije odluka koje kontroliraju brzine (stope) toka između stokova.
- postoje informacijski kanali koji povezuju funkcije odlučivanja sa stokovima.

Stokovi — nivoi — akumulacije

Stokovi su akumulacije unutar nekog sistema. To mogu biti zalihe raznih dobara, roba u transportu, bankovni bilansi, tvornički prostor, zemljišna površina, broj zaposlenih, raspoloživi osnovni proizvodni fondovi, itd. Stokovi su, zapravo, sadašnje vrijednosti onih varijabli koje su rezultirale iz akumulacije razlike između ulaza i izlaza. Naprimjer, broj zaposlenih u određenom razdoblju je stok koji rezultira iz broja zaposlenih u prethodnom razdoblju i razlike između broja novozaposlenih (ulaz) i broja onih koji su iz bilo kojeg razloga napustili posao (izlaz) u tekućem razdoblju. Osnovni proizvodni fondovi su stok koji rezultira iz stanja ovih fondova u prethodnom razdoblju i povećanja osnovnih fondova investiranjem te smanjenja deprecijacijom osnovnih proizvodnih fondova u tekućem razdoblju. U modelima sistemske dinamike mogu se javiti mreže tokova u kojima mogu postojati stokovi. Te mreže međusobno povezanih tokova mogu biti:

- mreža tokova materijala,
- mreža tokova novca,
- mreža tokova ljudi,
- mreža tokova narudžbi,
- mreža tokova kapitalne opreme,
- mreža tokova zemljišnih površina,
- mreža tokova informacija.

Stokovi, prema tome postoje ne samo u fizičkim mrežama tokova materijala nego, što je posebno važno u ovim modelima, i u mrežama tokova informacija. Tako možemo govoriti o »nivou svijesti« u mentalnim stavovima onih koji utječu na odluke. Nivoi zadovoljstva, optimizma, također utječu na ekonomsko ponašanje. Nivo svijesti inflatornih tendencija, naprimjer, utječe na opseg potrošnje, investicija, itd., dakle na određene tokove. Ili jednostavnije, nivo nedavne poslovne aktivnosti utječe na odluke o nabavkama i zalihama. Sve pamćenje i kontinuitet od prošlosti do budućnosti postoji u stokovima — nivoima sistema. Kao primjer informacijskog stoka — nivoa uzimamo prosječni nivo prodaje u protekloj godini. On se može mjeriti u komadima mjesečno ili dinarima mjesečno, naprimjer. To naravno nije brzina ili stopa u sistemskoj dinamici. To nije tok koji pokazuje, od trenutka do trenutka, sadašnju brzinu — stopu transfera između dva stoka. O

prosječnoj prodaji obično se govori kao o nivou — nivou prodaje ili nivou poslovne aktivnosti. Prosječni nivo prodaje dobije se integriranjem (sumiranjem) brzine — stope prodaje od trenutka do trenutka u nekom razdoblju, mjesecu na primjer.

Brzine — stope toka

Brzine — stope definiraju sadašnje, trenutne tokove između stokova sistema. Brzine odgovaraju aktivnostima, dok stokovi mjere realizirajuće stanje do kojeg je sistem doveden tom aktivnošću. Brzine toka određuju se na temelju stokova sistema ovisno o pravilima koja su definirana u funkcijama odluka. Za uzvrat, brzine toka određuju stokove.

Funkcije odluka

Funkcije odluka ili jednadžbe brzine toka predstavljaju iskaz politike koja određuje kako se raspoložive informacije o stokovima prevode u odluke (sadašnje brzine toka). Funkcije odluka mogu se odnositi na poslovne odluke, na odluke koje rezultiraju iz stanja u kojem je model datog sistema, ali i na odluke o investiranju ili potrošnji ako je u pitanju makroekonomski sistem.

Funkcija odluke se u modelu sistemske dinamike može pojaviti kao jednostavna jednadžba koja određuje, na neki elementaran način, brzine toka kao odgovor na stanje jednog ili dva stoka. S druge strane, funkcija odluke se može opisati i nizom složenijih računskih operacija kojima se vrednuje neki niz međufaznih koncepcija u odlučivanju. Da bismo mogli operirati s dinamičkim karakteristikama društvenih sistema, moramo imati mogućnost da predstavimo, u najmanju ruku, kostur strukture odlučivanja. Da bismo to uradili moramo aproksimirati kontrolne politike na svakoj značajnoj točki odlučivanja u sistemu. Ovo razumijevanje politike može se izvršiti ako:

— Imamo pravi koncept značenja odluke te možemo odrediti značenje politike koja opisuje proces odlučivanja.

— Imamo pravu strukturu koja povezuje status sistema s politikama, odlukama i akcijama.

— Shvatimo da je proces pod utjecajem smetnji pa ne treba visoka točnost predstavljanja procesa odlučivanja.

— Koristimo deskriptivne i iskustvene informacije koje čine većinu informacija bitnih za odlučivanje. Preaostale čine većinu informacija bitnih za odlučivanje. Preostale informacije mogu nam dati formalni statistički i numerički podaci.

— Shvatimo da formalan kvantitativan iskaz politike nema za neki način implikacije na apsolutnu točnost. Određivanje numeričkih vrijednosti ne poboljšava točnost originalnih deskriptivnih iskaza.

Oblik funkcija odluka

Model koji treba pravilno predstaviti ponašanje sistema zahtijeva formalan iskaz koji će pokazati kako se donose odluke. Ispuštanje odluke je kao da se poriče njeno postojanje, što može biti veća greška nego bilo koja greška u najboljim procjenama procesa. Općenito se može reći da ocjenjene funkcije odluka mogu biti dovoljno dobre da bi bile korisne. Perceptivno promatranje, istraživački razgovori s osobama koje odlučuju, proučavanje postojećih podataka te ispitivanje određenih primjera odluka i akcija, osvjettit će osnovne faktore koji utječu na odluke. U razmatranju faktora koji utječu na odluke možemo uspješno napredovati ako odgovorimo na četiri pitanja:

— Koji su faktori dovoljno značajni da se uključe u funkciju odluke?

A za svaki faktor:

— Koji je pravac njegovog utjecaja?

— Koji je opseg njegovog utjecaja?

— Mogu li se ustanoviti nelinearne veze?

Kada se formulira određena funkcija odluke u modelu, prvo treba pobrojati faktore koji značajno utječu na odluku. Odlučan test značajnosti nekog faktora u funkciji odlučivanja u modelu je da se promatra ponašanje modela sa i bez tog faktora. Međutim, u modelima koji se razvijaju na idejama industrijske dinamike razmjer direktnog utjecaja faktora na odluku nije jedini značajan faktor. U ovim modelima nužno je također razmotriti stupanj povratne veze ili posljedice odluke na faktore koji ulaze u odluku, te utvrditi trajanje takve povratne veze. Relativno slab utjecaj na odluku može biti značajan kod pozitivne povratne veze gdje varijabilni faktor utječe na odluku, a odluka utječe na ulazni faktor koji će pro-uzrokovati daljnju promjenu odluke.

Obično pravac utjecaja nekog faktora nije pod znakom pitanja. Međutim, često su kratkoročni i dugoročni utjecaji nekog faktora na odluku suprotnog smjera. U modelima sistemske dinamike treba o ovoj činjenici posebno voditi računa.

Dinamičko ponašanje sistema u kojima su ugrađene informacijske povratne veze određeno je načinom utjecaja promjene jedne varijable na promjenu druge varijable. Ovo može utjecati na očekivanje visoke

osjetljivosti sistema na točnost vrijednosti parametara u funkcijama odluka. Međutim, to obično nije tako. Ako je model pravilno konstruiran da bi prikazao stvarnu strukturu informacijskih povratnih veza društvenog sistema, on će imati istu samokorigirajuću prilagodljivost koja postoji i u stvarnom sistemu. Zato nas treba više zanimati što model kaže o faktorima koji će uzrokovati promjene u tokovima i stokovima, nego točnost u određivanju prosječne veličine tokova i stokova.

Može se reći da su linearni modeli oni u kojima vrijedi princip superpozicije. U linearnim modelima reakcije na svako uznemirenje odvijaju se neovisno od prethodnih ili narednih ulaza u sistem. Ukupan rezultat u linearnom sistemu je suma odvojenih komponenata izlaza sistema. Reakcija na neki ulaz je neovisna od trenutka ulaza ukoliko se radi o linearnom sistemu s konstantnim koeficijentima. U stvarnom linearnom sistemu mogu postojati samo opadajuće ili održavajuće oscilacije. Oscilacija koja raste nije ograničena i mora postati eksplozivno velika. To očigledno nisu karakteristike stvarnih ekonomskih sistema. Zato modeli industrijske dinamike sadrže nelinearne funkcije odluka. Nelinearnosti se u ovim modelima javljaju u funkcijama odluka koje određuju brzine toka. Ove nelinearnosti u funkcijama odluka mogu imati velik broj različitih oblika koje treba odrediti na osnovu poznavanja stvarne situacije. Treba naglasiti da je realistično ponašanje lakše postići u nelinearnim nego u linearnim modelima, jer nelinearni modeli brže vode do faktora o kojima ovisi ponašanje stvarnog sistema.

Aspekti informacijske povratne veze u sistemske dinamike

U modelima s informacijskom povratnom vezom uvjeti se konvertiraju u informacije koje su osnova za odluke, a odluke kontroliraju aktivnost koja će izmijeniti uvjete. Ovaj ciklus kontinuiran je tako da ne možemo govoriti o početku ili kraju ovog lanca. Reklo bi se da se radi o zatvorenoj petlji. Pritom je bitna opća koncepcija sistema u kojima je ugrađena informacijska povratna veza budući da ovi sistemi pokazuju ponašanje kao cjelina, što nije očigledno iz ispitivanja neovisnih dijelova. Oblici međusistemske povezanosti, pojačanja koja su uzrokovana odlukama i politikom, kašnjenja akcija iskrivljavanje informacijskih tokova, svi zajedno u međusobnoj povezanosti, određuju stabilnost i rast sistema.

Ponašanje sistema u koje je ugrađena informacijska povratna veza je usko povezano s vremenskim nizom veza između

akcija sistema. Vrlo značajna pojava u sistemu su kašnjenja koja se javljaju u svim stadijima aktivnosti sistema — u odlukama, u transportu, u prikupljanju podataka te u stokovima svih vrsta. Oblici kašnjenja u sistemu mogu biti razni, a u modelima sistemske dinamike treba im pokloniti posebnu pažnju.

Pojačanje je još jedna značajna karakteristika koja određuje ponašanje sistema s informacijskom povratnom vezom. »Pojačanje« se ovdje koristi kao netehnički termin koji podrazumijeva reakciju nekog dijela sistema koja je veća nego što bi se očekivalo na temelju uzroka te reakcije. Naprimjer, često se događa da fluktuacije u proizvodnji tvornica značajno prelaze visinu promjene prodaje na malo. Pojačanja se događaju na mnogim mjestima u ekonomskom sistemu. Ona se javljaju posebno u politikama koje definiraju odluke kojima se kontroliraju promjene tokova.

Informacija je ulaz u odluke, pa su odluke uvjetovane svim utjecajima koji djeluju na informacijske tokove. Informacija može biti izmjenjena ne samo kašnjenjem i pojačanjem, već i na drugi način. Tako se informacija mijenja postupcima uprosječenja i sumiranjem individualnih transakcija u zajedničke podatke koji služe izvršnim odlukama. Informacije, nadalje, sadrže greške i slučajne utjecaje te nepoznate perturbacije koje dolaze iz vanjskih izvora.

Informacija kao osnova za odluke

Funkcije odluka koje u sistemskoj dinamici određuju brzine toka ovise o informacijama o stokovima. Brzine toka ne određuju druge brzine toka. Ovo naravno vrijedi načelno. Naime, sadašnje — trenutne brzine tokova nisu na raspolaganju kao ulaz pri donošenju odluka. Ustvari sadašnje brzine toka su općenito nemjerljive. Ako dovoljno skratimo ono što podrazumijevamo pod »sadašnjim« vremenom, nemamo nikakvo znanje o drugim brzinama toka koje se događaju u isto vrijeme. Tako, na primjer, prodaju vlastite radne organizacije u sadašnjem trenutku nije moguće znati, ono što se obično podrazumijeva pod »sadašnjom« stopom zapravo su prosjeci (nivoi — stokovi) kao, naprimjer, prosječna tjedna prodaja, prosječna mjesečna prodaja, itd. Ako se vremenski interval dovoljno skratiti, u principu možemo utvrditi nemogućnost da određena odluka ovisi o nekoj drugoj sadašnjoj odluci koja se određuje u nekom drugom dijelu sistema u istom trenutku. Princip neovisnosti odluka je primjenjiv u praksi i efikasan je kao

ugaoni kamen formulacije modela. On ne dovodi do ograničavajuće kratkog vremenskog intervala računanja u modelu, a stvara mogućnost za formuliranje modela koji je oslobođen simultanih algebarskih jednadžbi.

Informacijska mreža u modelima sistemske dinamike počinje kod stokova i brzina tokova u ostalim mrežama i završava u funkcijama odluka koje generiraju brzine toka. Ova mreža prenosi informacije o stokovima do točaka odlučivanja, a informacije o brzinama toka u druge mreže. Naprimjer, informacije o stvarnoj sadašnjoj brzini toka ulaznih narudžbi se uprosječuju da bi se dobio stok — nivo prosječnog ulaza narudžbi. Informacijska mreža nadalje, sadrži različite »konceptije« koje su ulaz u proces odlučivanja, kao naprimjer, željena razina zaliha, projektirana veličina neophodnog postrojenja, prognoze inflacije, željena razina zaposlenosti, saznanja iz rezultata istraživanja itd. Osnovni dio modela obično je unutar informacijske mreže. U ekonomskim modelima obično se nastoji da novac odigra tu centralnu ulogu u odnosu na ostale aktivnosti. Mreža novca, međutim, ne daje odgovarajuće ulaze za donošenje svih ekonomskih odluka. Mreža tokova novca, može se reći, čini sažetak prošlih transakcija i igra ulogu ograničenja budućih odluka, ali nije dovoljan vodič za donošenje odluka.

5. Varijable stokova i tokova u dinamici osnovnih makroekonomskih agregata

U klasičnoj i suvremenoj ekonomskoj analizi ponuda i potražnja predstavljaju dva centralna koncepta. Ovisno o načinu tretiranja odnosa između ponude i potražnje modeli ekonomskih procesa se mogu podijeliti na dvije vrste:

— Modeli ravnoteže koji analiziraju ishod tržišnih transakcija kada su ponuda i potražnja nekog dobra u ravnoteži.

— Modeli neravnoteže koji tretiraju ponašanje ekonomije kada ponuda i potražnja nisu jednake.

U oba spomenuta pristupa postavlja se pitanje kako predstaviti osnovne sile ponude i potražnje koje djeluju na proizvodnju, promjenu cijena, plaće i druge ekonomske promjene. Moguća su dva različita stajališta u ovoj analizi. Prvo stajalište je dominantno u ekonomskoj misli i ono tretira ponudu i potražnju kao brzine toka. Na primjer J.M. Keynes u »Općoj teoriji zaposlenosti, kamate i novca« popularizira koncepciju agregatne potražnje koja je jednaka zbroju planirane potrošnje, investi-

cija i državnih izdataka. Ova tri oblika izdataka su tokovi, a mjere se u jedinicama dobara (novcu) u jedinici vremena. Čak davno prije Keynesa teorija poduzeća smatrala je ponudu tokom proizvodnje koju određuje izjednačavanje cijena i marginalnih troškova. Analogno tome, teorija domaćinstva tretirala je potražnju kao tok potrošnje koji je uvjetovan relativnim cijenama i graničnom korisnošću. Alternativa stajalištu koje ove varijable promatra kao brzine toka je ono koje ponudu i potražnju promatra prvenstveno kao varijable stoka, odnosno kao integracije. Prema ovom stajalištu, ponuda, naprimjer, treba biti mjerena raspoloživim zaliham dobara, dok se potražnja treba mjeriti količinom neispunjenih narudžbi.

Razlika između stokova i tokova ekonomistima je dobro poznata. Ipak ekonomske teorije se još uvijek prvenstveno okreću oko koncepta toka ponude i potražnje. Značajan razlog za ovaj naglasak na tokovima u ekonomiji je da su se teorija poduzeća i teorija domaćinstva razvile iz koncepcija maksimiranja profita i maksimiranja koristi. Teorija poduzeća određuje ravnotežu (brzinu) proizvodnju koja daje maksimalni tok profita, a teorija domaćinstva određuje ravnotežu (brzinu) nabave koja maksimizira tok korisnosti iz date nabave. U ravnoteži, zalihe poduzeća i domaćinstva su na željenoj razini. Prema tome, ne postoji odstupanje zaliha koje bi generiralo pritiske na povećanje ili smanjenje brzine proizvodnje i transakcija. Kao posljedica toga, zalihe i ostale varijable stokova ne javljaju se u modelima ravnoteže.

Ako želimo prikazati bogate karakteristike neravnotežnog ponašanja socio-ekonomskih sistema onda je nužno da koncept varijabli stokova u ponudi i potražnji bude eksplicitno sadržan u ekonomskim modelima. Kao što smo vidjeli modeli na idejama sistemske dinamike upravo su pravi put da se ove karakteristike uzmu u obzir i izraze u modelima. Određenije se može reći da, ukoliko postupimo, postoje brojne implikacije za ekonomsku teoriju i praksu modeliranja:

— Ravnoteža stokova i tokova, koje se obično definiraju u ekonomiji općenito se neće javiti zajedno. Tako će varijable stokova često biti izvan ravnoteže, čime će uzrokovati neprekidnu promjenu brzine toka, čak kada je jednom postignuta ravnoteža toka između proizvodnje i potrošnje. Prema tome, dinamičko ponašanje i karakteristike stabilnosti nekog ekonomskog sistema mogu biti pravilno analizirani samo ako se povežu varijable stokova i tokova.

— Ekonomski sistem karakteriziraju interakcije između stokova i tokova što stvara složene puteve do dostizanja ravnoteže. Takvi sistemi se ne mogu apriori smatrati stabilnim u tom smislu da će neka početna neravnoteža biti otklonjena u kratkom vremenu

— Efikasnost politike koja treba da utječe na takvo neravnotežno ekonomsko ponašanje kakav je rast ili nestabilnost može se pravilno procijeniti samo u modelu koji povezuje stokove i tokove.

Mehanizmi preko kojih varijable stokova utječu na dinamičku neravnotežu su slijedeći:

— Varijable stokova povezuju brzine toka.

— Varijable stokova mogu utjecati na nastajanje suprotnih kratkoročnih i dugoročnih efekata.

— Varijable stokova pojačavaju brzine toka kroz efekte akumuliranja.

— Varijable stokova podrazumijevaju različite načine ekonomskog ponašanja.

— Varijable stokova mogu širiti dugoročne ekonomske promjene.

— Varijable stokova mjere determinante ekonomskog blagostanja.

— Varijable stokova uzrokuju kašnjenja koja uzrokuju oscilacije u ponašanju ekonomskog sistema.

6) O tome više vidjeti u Mass, N. J.: Stock and Flow Variables and the Dynamics of Supply and Demand, u Randers, J.: Elements of the System Dynamics Method, MIT Press, Cambridge, 1980.

LITERATURA:

1. Babić, M.: Ekonometrijski model jugoslavenske privrede, Ekonomski institut Zagreb, Zagreb 1974.
2. Bole, V. — Mencinger, J.: Ekonometrični model jugoslavenskoga gospodarstva, Ekonomski institut pravne fakultete, Ljubljana 1980.
3. Coyle, R.G. — Sharp, J.A.: System Dynamics — Problems, Cases and Research, John Wiley and Sons, 1976.
4. Edward, A.L. — Graham, A.K.: Introduction to Urban Dynamics Cambridge, Wright-Allen Press, Inc., 1976.

5. *Forrester, J.W.*: Industrial Dynamics, MIT Press, Cambridge, 1969.
6. *Forrester, J. — Mass, N.J. — Ryan, C.J.*: The System Dynamics National Model: Understanding Socio-Economic Behavior and Policy Alternatives, Technological Forecasting and Social Change 9, 51-68, 1976.
7. *Forrester, N.B.*: The Life Cycle of Economic Development, Wright-Allen Press Inc., Cambridge, 1976.
8. *Mass, N.J.*: Economic Cycles: An Analysis of Underlying Causes, Wright-Allen Press, Inc., Cambridge, 1976.
9. *Meadows, D.L.*: Dynamics of Comodity Production Cycles, Wright-Allen Press, Inc., Cambridge, 1976.
10. *Meadows, D.H. — Meadows, D.L. — Randers, J. — Berens III, W.W.*: Graniće rasta, Stvarnost, Zagreb 1974.
11. *Randers, J.*: Elements of Systems Dynamics Method, MIT Press, Cambridge, 1980.
12. *Sojić, M.*: Metodi analize i predviđanja privrednih kretanja sa ekonometrijskim simulacijskim modelom za jugoslavenšku privredu. Institut društvenih nauka, Beograd 1981.
13. *Pfajfar, L. — Kranjec, M. — Kuzmin, F. — Simončić, M. — Kebrić, I.*: Upotreba ekonometrijskog modela u prognoziranju razvoja Jugoslavije za period 1981-1985, Economic analysis, Vol XV, No 2. pp. 143-161., Beograd 1981.

Dr. Branko Novak

Summary

SYSTEMS DYNAMICS AND ECONOMETRIC MODELS IN MODELLING ECONOMIC SYSTEMS

In this study two possible approaches to modelling economic systems are analysed; econometric approach and the one using ideas of systems dynamics. The former is in extensive use in the worldwide and domestic practice. Econometric approach is based on real, measurable facts. It requires more data, better measuring and new data. Econometric approach to economic models expresses the concept that world is essentially dual and open. Since environmental inputs can be very specific, by econometric models researches are made more of the peculiarities than of the similarities of various situations. Systems dynamics as a potential approach to modelling economic systems starts from the point of view that quantitative data make a smaller part of what we know, so it relies on different data sources. Furthermore, it tries to explain the behaviour of visible dynamic variables of the systems by its structure in whose basis are numerous feedback loops. In the structure of the dynamic systems models there is a clear difference between stock variables and flow variables. Systems dynamics assumes that he systems are primarily closed, so in these models attention is paid to general reactions to general disturbances as well as the dynamic behaviour of reactions and not the final systems position.